空气质量预测的深度学习模型研究与实践

黎嘉明[1]

[1]（广东省生态环境监测中心，广东 广州 510000）

摘要：

[目的] 及时和准确的空气质量预测数据对于环境管理至关重要，尤其是在空气重污染期间，预测数据可以为政府生态环境管理部门应对污染状况、精准地调配社会资源的决策提供数据支撑。

[方法] 笔者研发的基于深度学习的空气质量预测模型 AirNet6，可以兼顾准确性和实时性，实现臭氧、二氧化硫、一氧化碳等因子的 7 天甚至更长时间的空气质量预测。

[结果] 与传统的化学模型演算不同，本模型使用时空图卷积网络（STGCN），能捕获历史监测数据、天气预测数据、社会活动等数据的规律，在 2 分钟内完成一百多个点位未来 168 小时数据的预测。

[结论] 实验表明，AirNet6 模型在速度、节能和准确度上，比传统的化学模型及时间序列 AI 模型均有明显进步。

关键词：空气质量预测；人工智能；深度学习模型；时空图卷积网络

分类号：X823；TP183

Research and Practice of Deep Learning Model for Air Quality Prediction

Li JiaMing[1]

[1](Guangdong Eco-environment Monitoring Center, Guangzhou 510000, China)

Abstract:

[Objective] Timely and accurate air quality prediction data is very important for environmental management, especially during the period of heavy air pollution. The prediction data can provide data support for the decision-making of the government's ecological environment management departments to cope with the pollution situation and accurately allocate social resources.

[Methods] The air quality prediction model AirNet6 developed by the author based on depth learning can give consideration to both accuracy and real-time performance to achieve 7-day or longer air quality prediction for ozone, sulfur dioxide, carbon monoxide and other factors.

[Results] Unlike traditional chemical model calculations, this model base on Spatio-Temporal Graph Convolutional Networks (STGCN), which captures the laws of historical monitoring data, weather prediction data, social activities and other data, and completes the prediction of more than one hundred points for the next 168 hours in two minutes.

[Conclusions] Experiments show that the AirNet6 model has made significant progress in speed, energy efficiency, and accuracy compared to traditional chemical models and time series AI models.

Keywords: Air quality prediction； artificial intelligence； depth learning model； STGCN

引言

传统的基于化学模型的空气质量预测方法，一般是基于污染源排放数据、天气预测数据通过复杂的模拟运算得到结果，庞大的计算量需要用到大规模服务器集群甚至超级计算机等计算资源，并耗时数个小时才能生成结果，因此通常只能做到只能每天预测一次。而空气质量预测的数据对环境管理很重要，是政府做出决策、调配资源、采取应对措施的基本依据，在地方遭遇到重污染天气时，管理机构和专家需要实时应对天气和污染状况作出决策，往往一天就有几次会商量对策，这就需要更加及时反映当前时刻状况的预测数据，这个时候化学模型的计算速度就很难满足需求。

而随着人工智能技术的发展，常用的时间序列预测模型如 RNN、LSTM、Prophet 都可以根据历史的监测数据，比如前一小时的数据，推测出后续的数据变化，并且可以在短时间内完成，满足实时预测结果的需要。但时间序列的模型只是单纯地捕捉测点的数据随时间变化的规律，并没有考虑测点之间的关联因素，也没有关联天气的因素，因此准确度仍有不足。

为了同时提高准确度和计算速度，笔者基于时空图卷积网络（Spatio-Temporal Graph Convolutional Networks，STGCN）研发了新的深度学习模型，不只是利用了测点的历史空气质量数据以及它们的空间关联，还加入了相应的天气预测数据、社会活动数据等影响空气质量的因素，快速预测出 168 小时内的空气质量数据。STGCN 最早是用于交通网络的流量预测（Spatio-Temporal Graph Convolutional Networks: A Deep Learning Framework for Traffic Forecasting，2018），它由若干个时空卷积块和一个连接层组成，其中一个卷积块中包含了时间卷积层和空间卷积层，各自用于捕捉节点数据的时间特征和空间特征。

1. 模型设计

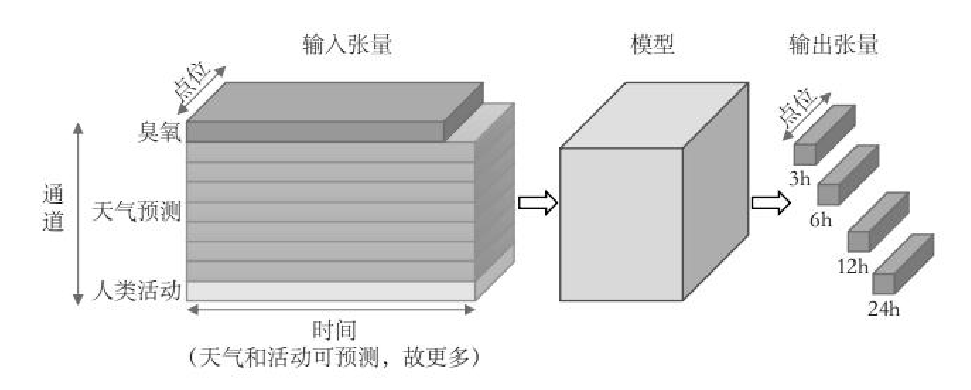


图 1 模型数据流图

Fig1. Model Data Flow Diagram

1.1 模型输入

如图 1 所示，模型输入的数据是一个 3 维张量（tensor），其中第一维是时间，粒度为一小时，例如以一年的数据作为输入，时间维度的长度为 365*24=8760。第二维是点位，例如广东的国控空气监测的点位有 125 个，点位维度的长度就为 125。第三维是通道，对应不同的因子，其中第一个通道是监测数据，例如 ozone 的监测数据，第二个通道开始的 7 个通道是天气预测的数据，分别是气压、光照、降水、温度、湿度、u 风速、v 风速，最后一个通道是社会活动数据。

其中，天气预测数据与社会活动数据是可预测的，因此它们的数据比历史监测数据多一些，例如，当需要预测 7 天后空气质量数据时，模型可以使用已经获取到的 7 天后的天气预测数据以及社会活动数据，而不是只使用当前的历史数据，这样可以令预测的结果更为准确。

另外，空气质量数据是基于监测点位的数据，而天气预测数据是网格数据，例如本模型使用的 NOAA（National Oceanic and Atmospheric Administration）的 GFS（The Global Forecast System）数据，是沿经纬度每 0.25 度一个数据。为了可以将这两种数据融入到一个模型中，需要把他们的空间域统一。因此，笔者使用监测点位作为统一的空间域，数据量可以大为减少，每个监测点位的天气预测数据，根据其位置通过插值得出。

此外，经研究测试，社会活动数据如污染源排放、经济活动、交通流量等微观数据很难准确、完整地收集，并且它们的时间与空间域跟监测数据相差很远，难以像气象数据那样整合。因此，笔者使用一个宏观的统计值作为社会活动量的可以预测的指标。由于社会活动的频繁程度主要与“工作日（w）”及“休息日（r）”的交替相关，通过对“前一日”、“当日”、“后一日”不同情况的枚举，得出 www、wwr、wrw、wrr、rww、rwr、rrw、rrr 这 8 种排列，通过对历史数据这 8 种情况的监测数据统计，就可以得出每个点位在这 8 中情况下 24 小时中的平均值，作为代表其社会活动频繁程度的经验值，如图 2 所示：

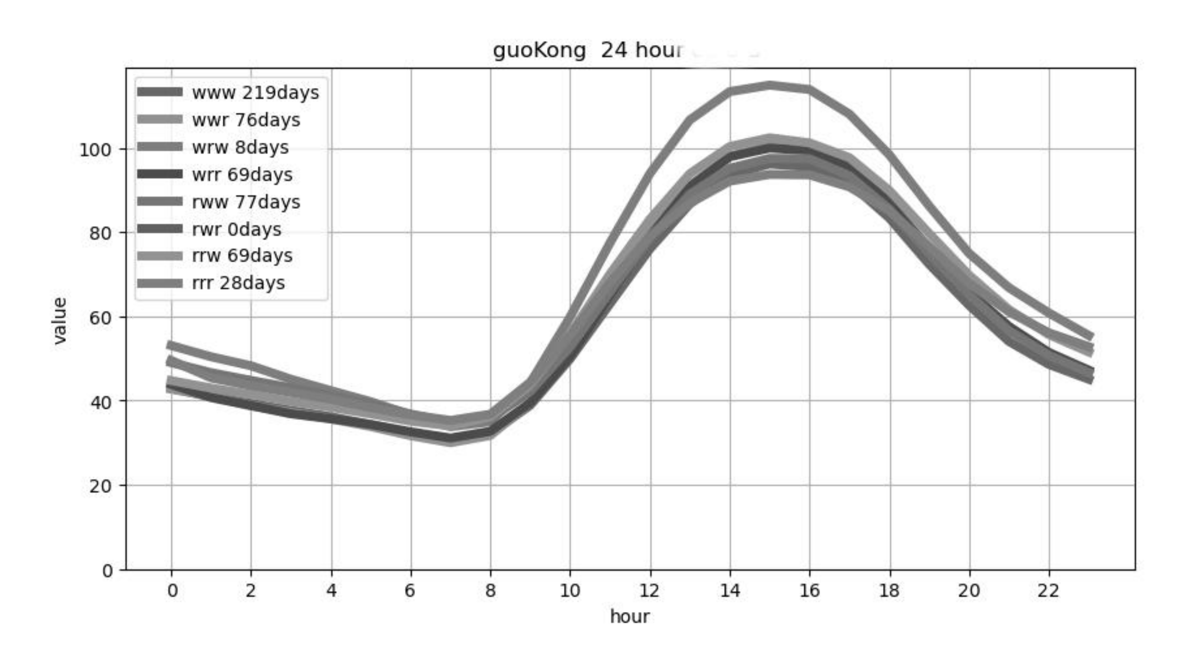


图 2 在 8 类工作日情况下的监测数据均值

Fig2. Mean monitoring data under 8 kinds of working day

1.2 网络结构

模型的网络结构如图 3 所示，模型的网络结构由三层时空卷积块和一层连接层组成，其中连接层有 4 个连接块，为了同时输出 4 个时间点的预测数据。时空卷积层中，第三层的时空卷积层与连接层对接，也是 4 个卷积块，分别对接到 4 个连接块，而前两层的时空卷积层只有统一的卷积块。

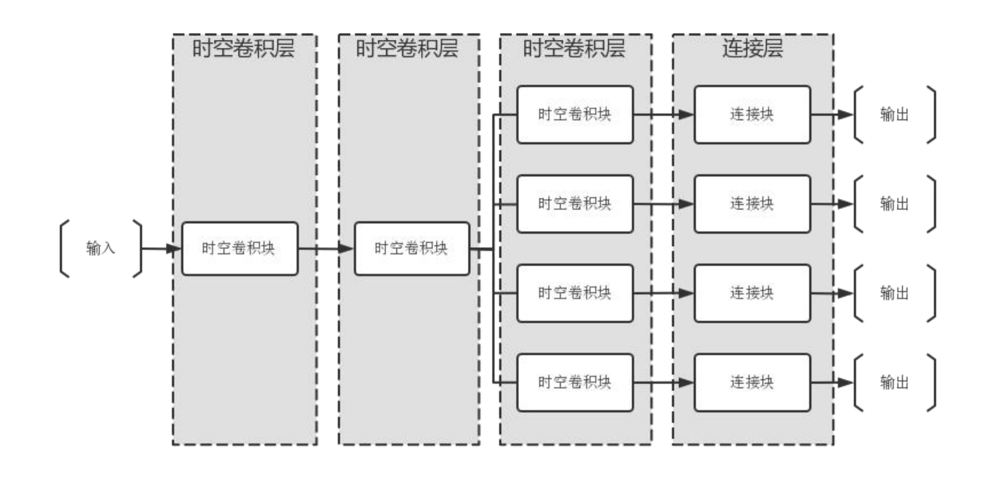


图 3 模型的网络结构图

Fig3. Network structure diagram of the model

1.3 模型输出

最初的模型输出的数据是一个 1 维张量，第一维是点位，数据代表这些点位在 n 个小时候后的时间点的空气质量。这就需要为每一个时间点训练一个模型，如果需要预测 7 天的空气质量数据，就要训练 7*24=168 个模型，而 6 个监测因子的话，就要训练 168*6=1008 个模型。

经研究迭代，使用时间移位的方法，每个因子只需要训练 8 个模型。方法是每个模型只预测 n=[3,6,12,24,48,72,120,168]8 个时间点的空气数据，这样就只需要 8*6=48 个模型。而这些时间点之间的数据，使用最靠近的后面的时间点模型计算得出，但输入数据需要相应前移获取。例如，时间点 10 没有对应的模型，就是用后面最靠近的 12 的模型，但输入数据需要前移 2 小时来取。

如图 4 所示，假设时间点 12 的模型需要输入 24 个小时的数据，当前时刻为 t，t 以及 t 以前的数据都已就绪；而预测 t+7~t+12 的数据，都使用时间点 12 的模型计算，其中预测 t+12 时，输入 t-23~t 的数据；预测 t+10 时，输入 t-25~t-2 的数据。

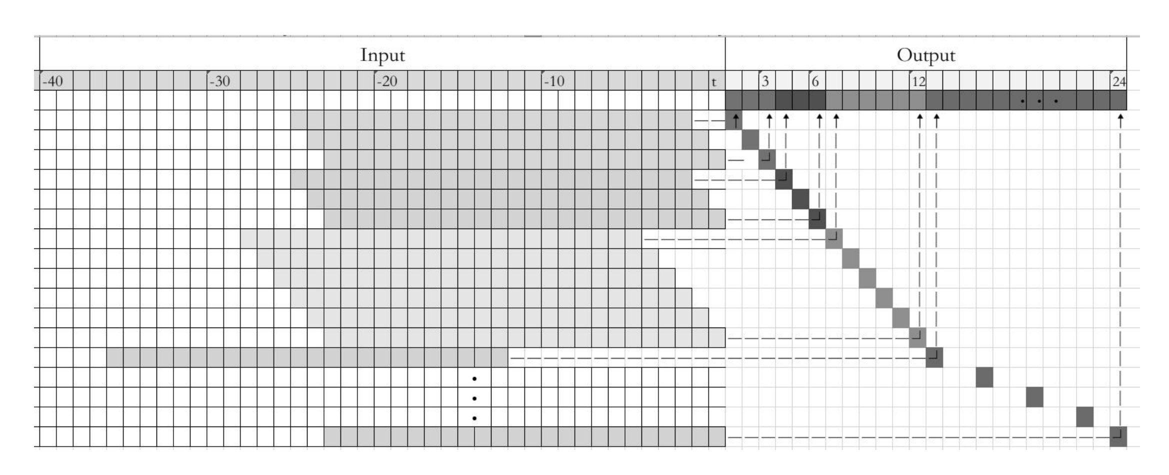


图 4 模型数据输入输出映射图

Fig4. Model data input output mapping diagram

同理，时间点 n 的模型可覆盖的预测时间，如表 1 所示：

表 1 时间点覆盖表

Table 1.Time point coverage

时间点 n 模型	覆盖预测时间
3	1h~3h
6	4h~6h
12	7h~12h
24	13h~24h
48	25h~48h
72	49h~72h
120	73h~120h
168	121h~168h

经进一步的研究迭代，将模型结构改为多输出（如图 3 所示），每个因子只需要训练 3 个模型，其中一个用于同时预测 n=[3,6,12,24]4 个时间点后的空气数据，一个同时预测 n=[48,72]两个个时间点，还有一个同时预测 n=[120,168]两个时间点，这样就只需要 3*6=18 个模型。经测试对比，将时间点作 4-2-2 的分割可以减少模型和训练模型的时间，而且准确率几乎没有下降。但若作 4-4 分割，后面 4 个时间点（48,72,120,168）的准确率有些下降，如果是用 1 个模型直接输出 8 给时间点，准确率更加会显著下降，因此 4-2-2 的分割是相对更好的选择。

最后，迭代后模型的输出，为一个 2 维张量，第一维是时间点，长度为 2 或者 4，代表 2 或者 4 个时间点，第二维度是点位。

2. 实验

2.1 数据集

笔者使用了广东省 125 个国控点的空气质量小时数据作为训练和验证模型的数据，包括臭氧、二氧化氮、一氧化碳、二氧化硫、PM10、PM2.5 六个监测因子，点位的经纬度坐标

用于与天气预测数据关联插值。

而天气预测的数据笔者使用 NOAA 的 GFS0.25 数据，空间范围是覆盖广东省的经纬度矩形（"north": 26,"west": 109,"south": 20,"east": 118）。其中，用于常规运行的实时 GFS 天气预测数据可从 NOMADS（NOAA Operational Model Archive and Distribution System）获取，而 GFS 的历史数据在 NOAA 的网站上只保留 8 天，因此历史的天气预测数据获取的渠道是 UCAR（University Corporation for Atmospheric Research），两个渠道使用的接口均为 OPeNDAP。

如前文所述，社会活动数据使用“工作日-休息日”宏观经验值，笔者使用 python holidays 模块和 chinese_calendar 模块获取假日数据，加上空气质量历史统计数据组成。

数据集的范围为 2021 年 4 月 1 日到 2022 年 10 月 1 日，其中 2021 年 4 月 1 日至 2022 年 7 月 1 日）的数据用于训练，2022 年 7 月 1 日至 2022 年 10 月 1 日的数据用于测试。即 5 个季度的数据用于训练，1 个季度的数据用于测试。

2.2 数据预处理

由于国控点的空气质量监测由在线监测设备产生，日常存在缺数据的现象，而模型不能输入空数据，所以需要先把缺失的数据补足。补足的方法是先用空间补足，即使用同一时间周边有数据的点位的数据，通过克里金插值的方法得出缺数据点位的数值。如果空间补足后仍有缺数据（这种情况一般为网络或者中心服务故障，导致同一时间大部分点位都没有数据），此时使用时间补足，用这个点位前一天的数据补足缺失的数据。

天气预测数据缺失不常见，而且因为天气预测数据冗余非常多（一个时间点的数据，之前几天都会预测到），只需要把前一天和后一天相应时间的数据赋值过来即可。

社会活动的宏观指标数据没有缺失，不需要补足。

对于所有的输入数据，在进入模型之前，规格化都是必须的，规格化就是把所有数值按比例压缩到[0,1]的范围，以利于神经网络计算。规格化的上下限值一般设置为样本数据（供训练的历史数据）的最大最小值，但为了训练出的模型能够适应样本以外的数据，笔者将上下限值扩展一倍。 设 S_{max}、S_{min}、S_{avg} 分别是所有样本数据的最大值、最小值和平均值，规格化的上限和下限使用以下公式：

$$Normalized_{max}=2\times S_{max}-S_{avg}$$

$$Normalized_{min}=2\times S_{min}-S_{avg}$$

2.3 实验设置

笔者使用 3 台 PC 进行训练及验证，每天 PC 配备一个 nvidia 3080 或 3090GPU 以提供算力，在训练时功耗约为 300w，每个模型的训练时间大概需要 2 小时。模型程序运行在 ubuntu20.04 和 python3.9 环境中，AI 框架使用 pytouch1.12.0，CUDA 版本为 11.7，并且为了加快计算速度和减少 GPU 内存使用，模型全程使用 float32 类型进行运算。

2.4 实验结果

根据《环境空气质量数值预报技术规范（HJ 1130-2020）》中的“6.2 单项污染物浓度预报统计评估”，计算 4 个模型在预测 2022 年 7 月 1 日至 2022 年 10 月 1 日各因子预报结果与实况的偏差、误差和相关性，实验结果如下：

（1）标准化平均偏差 （Normalized Mean Bias, NMB）

表 2 标准化平均偏差结果比较

Table 2. Comparison of standardized mean deviation results

因子	模型	Day1	Day2	Day3	Day4	Day5	Day6	Day7	平均
O3									
	AirNet6	-6%	-11%	-9%	-13%	-13%	-13%	-13%	-11%
	Prophet	-18%	-18%	-17%	-17%	-18%	-18%	-19%	-18%
	lstm	-22%	-24%	-23%	-23%	-23%	-23%	-24%	-23%
	化学模型	50%	57%	65%	71%	74%	73%	66%	65%
	化学模型(修偏)	-9%	-5%	0%	4%	5%	5%	1%	0%
NO 2									
	AirNet6	0%	1%	3%	0%	-1%	2%	2%	1%
	Prophet	-14%	-14%	-15%	-15%	-16%	-16%	-16%	-15%
	lstm	22%	21%	21%	21%	20%	20%	20%	21%
	化学模型	49%	55%	55%	53%	55%	50%	48%	52%
	化学模型(修偏)	-2%	2%	2%	1%	2%	-1%	-3%	0%
CO									
	AirNet6	-6%	-8%	-6%	-4%	-4%	-2%	-2%	-4%
	Prophet	-8%	-8%	-8%	-8%	-8%	-8%	-8%	-8%
	lstm	35%	37%	36%	36%	36%	35%	35%	36%
	化学模型	-47%	-47%	-47%	-46%	-45%	-45%	-47%	-46%
	化学模型(修偏)	-1%	-2%	-1%	1%	3%	1%	-1%	0%
SO 2									
	AirNet6	-9%	-13%	-12%	-13%	-13%	-12%	-13%	-12%
	Prophet	-9%	-10%	-10%	-10%	-10%	-10%	-10%	-10%
	lstm	9%	10%	9%	9%	9%	9%	9%	9%
	化学模型	7%	10%	14%	17%	18%	13%	9%	13%
	化学模型(修偏)	-5%	-2%	2%	4%	5%	0%	-2%	0%
PM 10									
	AirNet6	-4%	-5%	-8%	-7%	-7%	-9%	-9%	-7%
	Prophet	-23%	-23%	-23%	-23%	-24%	-24%	-24%	-23%
	lstm	-13%	-13%	-13%	-13%	-13%	-12%	-13%	-13%
	化学模	-43%	-43%	-42%	-40%	-41%	-42%	-46%	-42%

	型								
	化学模型(修偏)	-2%	-1%	-1%	4%	2%	-1%	-7%	-1%
PM 2.5									
	AirNet6	-10%	-23%	-13%	-18%	-17%	-17%	-17%	-16%
	Prophet	-29%	-29%	-29%	-29%	-30%	-30%	-30%	-30%
	lstm	-13%	-13%	-13%	-13%	-14%	-15%	-16%	-14%
	化学模型	-29%	-29%	-29%	-24%	-25%	-27%	-33%	-28%
	化学模型(修偏)	-1%	-2%	-1%	6%	3%	1%	-7%	0%

由于化学模型偏差较大，对其数据做初步的修偏处理（除以(1+偏差)）的处理后，得到"化学模型（修偏）"数据

（2）均方根误差（Root Mean Square Error, RMSE）

表 3 均方根误差结果比较

Table 3. Comparison of root mean square error results

因子	模型	Day1	Day2	Day3	Day4	Day5	Day6	Day7	平均
O3									
	AirNet6	33.55	36.37	35.32	38.65	38.78	38.96	39.01	37.23
	Prophet	42.80	44.57	45.59	46.50	47.22	47.74	48.19	46.09
	lstm	51.79	53.06	52.97	52.71	52.91	52.97	53.04	52.78
	化学模型	55.19	56.14	60.57	63.84	65.01	64.36	63.73	61.26
	化学模型(修偏)	43.78	42.79	43.63	43.91	43.35	43.45	45.31	43.75
NO 2									
	AirNet6	9.45	9.76	10.02	9.94	9.95	10.22	10.21	9.94
	Prophet	10.66	10.79	10.86	10.92	10.98	11.06	11.13	10.91
	lstm	18.90	14.93	14.94	14.92	14.91	14.91	14.93	15.49
	化学模型	24.48	25.10	25.89	25.44	25.64	24.62	24.79	25.14
	化学模型(修偏)	16.44	16.73	17.28	17.05	17.09	16.55	16.79	16.85
CO									
	AirNet6	0.37	0.40	0.40	0.38	0.37	0.37	0.37	0.38
	Prophet	0.37	0.37	0.37	0.37	0.37	0.37	0.37	0.37
	lstm	0.49	0.50	0.49	0.49	0.49	0.49	0.49	0.49
	化学模型	0.47	0.48	0.48	0.48	0.47	0.45	0.47	0.47
	化学模型(修偏)	0.50	0.50	0.51	0.51	0.51	0.48	0.49	0.50

SO 2									
	AirNet6	14.71	14.98	14.92	14.99	14.90	14.71	14.69	14.84
	Prophet	14.71	14.95	14.91	14.91	14.82	14.71	14.70	14.82
	lstm	15.37	15.31	15.26	15.25	15.15	15.03	15.00	15.20
	化学模型	16.18	16.00	16.11	16.41	16.19	15.92	15.84	16.09
	化学模型(修偏)	15.80	15.60	15.68	15.97	15.73	15.49	15.43	15.67
PM 10									
	AirNet6	15.32	16.72	16.70	18.38	18.43	17.58	17.60	17.25
	Prophet	19.87	20.70	21.17	21.58	21.88	22.15	22.46	21.40
	lstm	21.96	22.26	22.41	22.44	22.60	22.73	22.75	22.45
	化学模型	22.87	22.80	23.72	23.60	23.06	23.39	24.32	23.39
	化学模型(修偏)	25.85	25.70	27.15	27.80	26.54	26.52	26.17	26.53
PM 2.5									
	AirNet6	10.07	11.41	10.31	12.00	12.04	11.66	11.66	11.31
	Prophet	12.82	13.48	13.80	14.09	14.31	14.51	14.75	13.97
	lstm	14.23	14.32	14.30	14.39	14.43	14.40	14.32	14.34
	化学模型	14.01	13.99	14.86	15.00	14.29	14.47	14.59	14.46
	化学模型(修偏)	16.44	16.31	17.32	18.01	16.87	17.00	16.43	16.91

（3）相关系数 （Correlation coefficient, r）

表 4 相关系数结果比较

Table 3. Comparison of correlation coefficient results

因子	模型	Day1	Day2	Day3	Day4	Day5	Day6	Day7	平均
O3									
	AirNet6	0.79	0.76	0.77	0.73	0.73	0.72	0.72	0.74
	Prophet	0.66	0.61	0.59	0.57	0.55	0.54	0.53	0.58
	lstm	0.42	0.40	0.40	0.41	0.41	0.41	0.41	0.41
	化学模型	0.44	0.45	0.43	0.42	0.45	0.48	0.45	0.45
	化学模型(修偏)	0.44	0.45	0.43	0.42	0.45	0.48	0.45	0.45

NO 2									
	AirNet6	0.70	0.67	0.67	0.67	0.67	0.65	0.65	0.67
	Prophet	0.61	0.60	0.59	0.59	0.59	0.58	0.57	0.59
	lstm	0.21	0.28	0.27	0.27	0.27	0.27	0.27	0.26
	化学模型	0.34	0.32	0.30	0.30	0.30	0.32	0.32	0.32
	化学模型(修偏)	0.34	0.32	0.30	0.30	0.30	0.32	0.32	0.32
CO									
	AirNet6	0.26	0.15	0.15	0.13	0.13	0.13	0.13	0.16
	Prophet	0.29	0.27	0.26	0.25	0.24	0.23	0.22	0.25
	lstm	0.02	0.03	0.03	0.03	0.03	0.03	0.03	0.03
	化学模型	0.09	0.07	0.05	0.05	0.06	0.08	0.08	0.07
	化学模型(修偏)	0.09	0.07	0.05	0.05	0.06	0.08	0.08	0.07
SO 2									
	AirNet6	0.18	0.16	0.16	0.13	0.13	0.16	0.16	0.16
	Prophet	0.18	0.17	0.17	0.16	0.16	0.16	0.16	0.17
	lstm	0.04	0.06	0.06	0.06	0.06	0.06	0.06	0.06
	化学模型	0.00	0.00	-0.01	-0.01	-0.01	-0.01	-0.01	-0.01
	化学模型(修偏)	0.00	0.00	-0.01	-0.01	-0.01	-0.01	-0.01	-0.01
PM 10									
	AirNet6	0.70	0.63	0.63	0.53	0.53	0.58	0.58	0.59
	Prophet	0.50	0.43	0.39	0.35	0.33	0.31	0.29	0.37
	lstm	0.16	0.13	0.10	0.09	0.07	0.05	0.04	0.09
	化学模型	0.21	0.17	0.08	0.10	0.12	0.15	0.16	0.14
	化学模型(修偏)	0.21	0.17	0.08	0.10	0.12	0.15	0.16	0.14
PM 2.5									
	AirNet6	0.68	0.61	0.66	0.51	0.50	0.54	0.54	0.58
	Prophet	0.49	0.40	0.36	0.32	0.29	0.28	0.25	0.34

lstm	0.08	0.06	0.06	0.04	0.03	0.04	0.05	0.05
化学模型	0.20	0.18	0.08	0.11	0.13	0.16	0.19	0.15
化学模型(修偏)	0.20	0.18	0.08	0.11	0.13	0.16	0.19	0.15

根据实验的结果可知，AirNet6 在预测六个监测因子中，臭氧、二氧化氮、PM10、PM2.5 这四个的准确率都明显优于其他模型，而一氧化碳、二氧化硫这两个因子的准确率与 Prophet 很接近且明显优于其他模型。

3. 常规化运行

模型训练完后通常可使用一个季度到一年，因为模型只是捕捉了训练数据（本文使用的是 2021 年 4 月 1 日至 2022 年 7 月 1 日的数据）的规律，当内、外环境因素有变化后，模型的预测准确率会下降，届时需要重新使用新的训练数据重新训练模型，以获得更匹配的预测结果。

模型在常规化运行时，不需要进行训练，只需要使用训练好的模型进行推演，因此消耗的资源非常小，在一台普通配置的 PC（CPU AMD Ryzen 7 1700，GPU nvidia 970），在 2 分钟内就可完成 6 个因子 168 小时的预测，可以在生产中实现密度为每小时一次的预测，有助于重污染天气的应对。

4. 资源消耗比较：

	训练耗时	训练硬件需求	常规运行耗时	常规运行硬件需求	源数据需求
AirNet6	2 天	3080GPU	2 分钟	普通 PC	历史数据、天气预测
Prophet	无	无	6 小时	普通 PC	历史数据
LSTM	1 天	3080GPU	1 分钟	普通 PC	历史数据
化学模型	无	无	6 小时	服务器集群	历史数据、天气预测、源清单

表 5 资源消耗比较

Table 3. Comparison of Resource consumption

5. 结论和未来工作

在本文中，笔者总结了一种新的深度学习模型的研究与实践，捕捉一片区域的空气质量随时间变化及随天气和社会活动的规律，快速而准确的预测未来的空气质量数据。实验表明，在真实的广东省近年的国控数据集上，新的模型优于其他方法，这对于实施更加精细的环境管理是十分有用的。

未来，笔者会继续优化迭代模型，提高它的准确性和适用范围（如河流水质监测、噪声监测）。

参考文献：

(1) Bing Yu , Haoteng Yin, Zhanxing Zhu , Spatio-Temporal Graph Convolutional Networks: A Deep Learning Framework for Traffic Forecasting，arXiv:1709.048

(2) Tomasz Sta´nczyk and Siamak Mehrkanoon，Deep Graph Convolutional Networks for Wind Speed Prediction，arXiv:2101.10041 [cs.LG]

(3) Yi-Fan Zhang1(B) , Peter J. Thorburn1 , and Peter Fitch2，Multi-task Temporal Convolutional Network for Predicting Water Quality Sensor Data , https://link.springer.com/chapter/10.1007/978-3-030-36808-1_14

(4) Taylor SJ, Letham B. 2017. Forecasting at scale. PeerJ Preprints 5:e3190v2 https://doi.org/10.7287/peerj.preprints.3190v2

(5) Fjellstrom, C. (2022). Long Short-Term Memory Neural Network for Financial Time Series. 2022 IEEE International Conference on Big Data (Big Data).https://arxiv.org/abs/2201.08218

作者贡献声明：

黎嘉明：提出研究思路，设计研究方案，设计实施实验，撰写论文；